

# Classification de données LiDAR bi-spectral topo-bathymétriques par une approche multi-échelle : Application en milieu fluvial

Arthur Le Guennec<sup>1</sup>  
Sébastien Lefèvre<sup>2</sup>

Dimitri Lague<sup>1</sup>  
Thomas Corpetti<sup>3</sup>

<sup>1</sup> Univ Rennes, CNRS, Géosciences Rennes - UMR 6118, F-35000 Rennes, France

<sup>2</sup> Univ. Bretagne Sud, IRISA, OBELIX - UMR 6074, F-56000 Vannes, France

<sup>3</sup> Univ Rennes, CNRS, LETG - UMR 6554, F-35000 Rennes, France

arthur.leguennec@univ-rennes1.fr  
dimitri.lague@univ-rennes1.fr  
sebastien.lefevre@irisa.fr  
thomas.corpetti@univ-rennes2.fr

## Résumé

*Le suivi d'un espace naturel/semi-naturel requiert souvent d'identifier automatiquement les différents objets présents tels que la végétation, le sol, l'eau, les bâtiments, etc. Dans le contexte fluvial, la détection des classes bathymétriques (surface et fond de l'eau principalement) est essentielle pour de nombreuses applications, comme la gestion des rivières ou cours d'eaux par exemple. Afin de les obtenir, le LiDAR topo-bathymétrique est un outil intéressant car il permet de construire deux nuages de points 3D à une très grande résolution spatiale des scènes scannées à partir de deux longueurs d'onde spécifiques : 1064 nm et 532 nm. L'aspect topographique, porté par la longueur d'onde à 1064 nm, permet de récupérer la structure spatiale des différents objets. Le côté bathymétrique provient de la longueur d'onde 532 nm pénétrant dans l'eau et permettant parfois d'accéder jusqu'au fond de rivière. Ainsi, classer les différents objets topo-bathymétriques à partir de ces deux nuages de points est un enjeu essentiel. Dans cet article, nous étendons l'approche multi-échelle permettant de caractériser les structures spatiales, qui a déjà démontré ses performances pour l'analyse de nuages de points, avec de nouveaux descripteurs prenant notamment en considération l'aspect bi-spectral. La classification est réalisée au moyen d'une technique de forêts aléatoires qui offre la possibilité d'analyser les descripteurs les plus informatifs dans la classification, et donc de mieux comprendre l'impact de la donnée bispectrale.*

## Mots Clef

LiDAR, analyse multi-échelle, Classification, Forêts aléatoires, Bi-spectral.

## Abstract

*The monitoring of a natural/semi-natural space often requires the automatic identification of the various objects present such as vegetation, soil, water, buildings, etc. In the fluvial context, the detection of bathymetric classes (surface and mainly water bottom) is essential for many applications, such as the management of rivers or streams. In order to obtain them, the topo-bathymetric LiDAR is an interesting tool because it makes it possible to construct two 3D point clouds at a very high spatial resolution of the scenes scanned from two specific wavelengths: 1064 nm and 532 nm. The topographic aspect, by the wavelength 1064 nm, allows to recover the spatial structure of the different objects. The bathymetric aspect comes from the wavelength 532 nm entering the water and sometimes allowing access to the bottom of the river. Thus, classifying the different topo-bathymetric objects from these two points clouds is an essential issue. In this article, we extend the multi-scale approach to characterize spatial structures, which has already demonstrated its performance for point cloud analysis, with new descriptors taking into consideration the bi-spectral aspect. The classification is carried out using a technique of Random Forest which offers the possibility to analyze the most contributive descriptors in the classification and thus to better understand the impact of the bispectral data.*

## Keywords

LiDAR, Multi-scale analysis, Classification, Random Forest, Bi-spectral.

# 1 Introduction

La classification des données de télédétection est un domaine très riche étudié pour de nombreuses applications (suivi environnemental, végétation urbaine, archéologie, ...) [7, 20] et à l'aide d'un très vaste panel d'approches méthodologiques (SVM, Deep learning, ...) [7, 21].

La plupart de ces approches ont été développées pour des données images (données *raster* réparties sur une grille régulière de pixels) et toutes ne sont pas directement transférables aux nuages de points 3D issus de données LiDAR. En effet, ces points ne sont pas répartis de manière homogène sur la scène (cela dépend de celle-ci) et plusieurs retours peuvent être issus d'un même tir car les lasers pénètrent la canopée. Il est donc possible d'extraire les différents pics de retour d'onde, ce qui permet ainsi d'accéder à la structure d'objets comme des feuilles. Dans notre application, nous utilisons un laser bi-spectral qui fournit des nuages de points issus de deux longueurs d'onde, le proche infra-rouge de 1064 nm (nommé *canal PIR* dans la suite), et le vert de 532 nm (nommé *canal vert* dans la suite).

La classification de données LiDAR est un problème plus récent et certaines techniques performantes ont été proposées au cours de la dernière décennie [5, 14, 16]. Ces méthodes ont pour la plupart été développées dans un contexte "monospectral" (un seul tir laser). Notre objectif ici est de montrer les possibilités du LiDAR bi-spectral dans la classification à la fois de la scène et de la bathymétrie.

Notre article est suivra donc le plan suivant. Nous présenterons tout d'abord un état de l'art sur la classification de données LiDAR (Sec. 2). Nous décrirons ensuite le jeu de données utilisé (Sec. 3) et détaillerons la méthode proposée dans cet article (Sec. 4). Nous présenterons et analyserons les résultats obtenus en Sec. 5 avant de conclure et d'identifier des perspectives de recherche à ces travaux.

## 2 État de l'art

Dans cette section, nous dressons d'abord un panorama des descripteurs relatifs au nuage de points (comme l'intensité) et calculés par rapport à un voisinage local. Puis, nous traiterons du cas des données multi-spectrales, utilisées dans cet article. Pour finir, nous nous intéresserons à l'usage des données LiDAR en bathymétrie.

### 2.1 Caractérisation de nuages de points

La caractérisation d'un point dans un ensemble structuré peut s'effectuer à partir des propriétés *ponctuelles* de ce point (intensité par exemple) mais aussi en lui associant des propriétés liées à son *voisinage*. Nous discutons ici ces deux approches.

**Descripteurs ponctuels** La manière la plus évidente est de caractériser un point par son intensité et éventuellement le numéro du retour d'onde dont il est issu. Cette information est en général directement issue des données et ne nécessite aucun traitement supplémentaire. Le principal désavantage de ces descripteurs est qu'ils sont souvent liés

aux paramètres de vol et du capteur. L'intensité, par exemple, dépend fortement de l'altitude à laquelle l'acquisition a été réalisée et de la nature du système d'acquisition. Les auteurs dans [17] proposent un algorithme afin de calibrer l'intensité mais cela ne fonctionne principalement que dans des milieux urbains, où les surfaces des objets ciblés sont en général bien définies.

**Descripteurs basés sur le voisinage** Ces descripteurs sont calculés en chaque point en lui associant des informations sur son voisinage. Dès lors, plusieurs types de voisinage peuvent être utilisés, comme un voisinage sphérique [5], caractérisé par un centre et un rayon, un voisinage cylindrique [8], ou encore un voisinage par plus proche voisin (kNN) [19]. Dans cette étude, nous utilisons un voisinage sphérique en raison de sa simplicité de calcul et de ses bonnes performances [5]. Dès lors qu'un voisinage est mis en jeu, la question de la *taille* de ce voisinage apparaît. En effet, si celui-ci est trop petit, la structure à laquelle appartient un point ne sera probablement pas prise en considération dans sa description mais, s'il est trop grand, l'information précise autour de ce point pourra diminuer. Ainsi, une approche multi-échelle, qui prend en compte différentes tailles de voisinages, permet de s'affranchir partiellement de ce problème [5, 2]. Comme cela est montré dans [5], les descripteurs multi-échelles offrent de meilleures performances en termes de classification par rapport à l'utilisation de descripteurs à échelle fixe.

De manière générale, les descripteurs basés sur le voisinage peuvent être regroupés en trois familles :

- Par structure 3D : il s'agit ici de dériver des descripteurs informant sur la structure 3D du voisinage d'un point (plan, orienté, homogène par exemple). Pour cela, l'analyse en composante principale (ACP) est souvent utilisée pour calculer les valeurs propres  $\lambda_i$  ( $i \in 1, 2, 3$  avec  $\lambda_1 \geq \lambda_2 \geq \lambda_3$ ), dont le rapport entre elles renseigne sur la dimensionnalité du voisinage englobant le point (1D, 2D ou 3D). Dans [5], les auteurs utilisent le rapport des deux premières valeurs propres de l'ACP (la troisième étant corrélée aux deux premières) pour dériver un critère d'orientation générale, tandis que d'autres travaux [2, 14] combinent ces valeurs propres pour calculer des informations telles que l'omnivariance ( $O_\lambda = \sqrt[3]{\lambda_1 \lambda_2 \lambda_3}$ ) ou la planéarité ( $P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1}$ )
- Par structure verticale : ces descripteurs sont calculés soit par variation de l'altitude locale [10] soit par différence entre le point traité et le point le plus bas trouvé (supposé être le sol) [3] en le recherchant dans un grand voisinage [9]. Cette différence d'altitude a pour inconvénient d'être dépendante du type de topographie, un terrain en pente pouvant donner lieu à des descripteurs non pertinents.
- Par variation d'intensité : bien que l'intensité soit fortement dépendante des paramètres d'acquisition

des données, il est possible de distinguer des surfaces selon leurs rapports d'intensité [6]. Dans le cas de données à retour d'onde complète (tout le signal rétro-diffusé est analysé et non les seuls pics d'intensité), on peut également calculer l'asymétrie des échos ou encore son aplatissement pour séparer le sol de la végétation [1]. Bien entendu, cela nécessite d'avoir corrigé l'intensité, et la difficulté ici consiste à extraire des descripteurs les plus indépendants possibles des outils d'acquisition.

Notons que ces descripteurs sont généralement calculés à partir d'un seul nuage de points et provenant d'une seule longueur d'onde. Comme mentionné plus haut, des capteurs récents comme le LiDAR bi-spectral utilisé dans cet article, permettent d'exploiter plusieurs canaux. Dans cette étude, nous combinerons les points issus de ces deux canaux pour analyser le bénéfice des données bi-spectrales.

## 2.2 Descripteurs de données multi-spectrales

Les données LiDAR multi-spectrales sont plus récentes et certains auteurs ont proposé l'exploitation du canal vert pour mesurer la bathymétrie dans les milieux côtiers et comprendre la pénétration de ce canal dans l'eau, laquelle est liée à la turbidité de l'eau [13]. Dans [20], des données provenant d'un LiDAR multi-spectral à trois canaux (infrarouge à 1550 nm, proche infra-rouge à 1064 nm et vert à 532 nm) sont utilisées dans un contexte urbain. Ici, on émet l'hypothèse sous-jacente que les points issus de chaque canal se superposent, autorisant ainsi la comparaison directe des différences d'intensité. Par ailleurs, cela requiert une bonne calibration des intensités des différents canaux, ce qui n'est pas le cas de nos données. Ainsi, cet article utilise plutôt les nouvelles informations liées à l'intensité qu'apporte le multi-spectral, mais ne traite pas les nouvelles informations liées à la géométrie du nuage.

Comme on le verra dans la section 4, nous proposerons à la fois des descripteurs basés sur la géométrie en mélangeant les deux nuages de points (pour obtenir une information plus dense) et des descripteurs s'appuyant sur les rapports d'intensité par une approche multi-échelle.

## 2.3 Détection de la surface de l'eau

Détecter la surface d'eau est d'un grand intérêt pour de nombreuses applications, comme par exemple la prévision d'inondation ou encore le transport de sédiments.

Cette détection peut se faire par imagerie aérienne ou satellite [11] mais cela ne fonctionne que pour des rivières assez larges par rapport à la résolution spatiale de l'image. Ainsi les données LiDAR sont très utiles ici. Dans [10], les auteurs utilisent la rugosité de la surface, calculée par analyse de l'écart-type de l'altitude dans un voisinage, et la variation de l'intensité pour détecter la surface en eau. Cette dernière approche donne des résultats satisfaisants malgré

une confusion importante entre la surface de l'eau et les routes en termes de rugosité et d'intensité.

À l'inverse, la plupart des études traitant de la bathymétrie avec le LiDAR requièrent une connaissance préalable de la surface en eau. Ainsi, dans [18], les auteurs distinguent les différents types de fond selon le retour d'onde complète du canal vert et dans [15], l'exploitation des données à retour d'onde complète d'un LiDAR embarqué sur un kayak permet de mesurer la bathymétrie.

Dans cet article, nous nous intéresserons conjointement à la classification de la surface en eau et à la bathymétrie. Les surfaces en eau seront extraites en utilisant des descripteurs calculés sur les nuages de points bruts des canaux infrarouge et vert et dans un deuxième temps, la classification du fond de l'eau sera effectuée sur ces surfaces. Les descripteurs, tels que la rugosité comme dans [10], seront utilisés et enrichis en utilisant le second canal disponible.

## 3 Données

Les jeux de données utilisés ici ont été acquis sur la rivière de l'Ain, en France, par le LiDAR Titan Optech, un LiDAR topo-bathymétrique tirant dans les longueurs d'onde PIR et vert. Le jeu complet contient près de 10 milliards de points et une grande diversité d'objets, tels que de la végétation, des champs, des ponts, des fils électriques, des bâtiments, etc. Pour mettre au point notre méthode et la valider, nous avons dû étiqueter ces données et nous nous sommes ainsi focalisés sur une sous-zone. De plus, afin d'optimiser les temps de calcul, les nuages de points ont été sous-échantillonnés et divisés en patchs de  $15m \times 15m$ , avec des espacements entre patchs de  $10m$ . Ainsi, puisque des descripteurs prennent en compte un voisinage spatial dans leurs calculs, les points utilisés dans chaque patch ne sont pas utilisés dans les autres. Deux validations croisées seront faites, d'une part pour déterminer les paramètres du classifieur par forêts aléatoires, et d'autre part pour calculer les résultats effectifs de classification. La validation croisée permet de diviser l'ensemble de nos données en  $k$  parties (ici  $k = 10$ ), d'en sélectionner  $k - 1$  pour entraîner notre classifieur, et une pour le tester. Ainsi, les résultats mesurés sont plus robustes au découpage des données.

La table 1 montre le nombre de points disponibles dans le canal PIR pour chaque classe utilisée ici (Sol, Surface de l'eau, Végétation, Bâtiments) avec l'écart-type par échantillon de validation croisée, car le nombre de points par classe varie selon les parties de validation croisée utilisées. Nous présentons maintenant notre méthodologie.

## 4 Méthodologie

Nous proposons ici d'utiliser des descripteurs multi-échelles et multi-spectraux. Afin de déterminer quels ont été les descripteurs les plus déterminants, nous utilisons une méthode de classification de type forêts aléatoires [4] qui, outre de très bonnes performances, offre l'avantage d'associer à chaque descripteur sa contribution dans la classification des données. Le principe des forêts aléatoires

Canal	Classes	Total	Données d'entraînement	Données de test
Proche Infra-Rouge	Sol	70 938	90% ( $\pm 1.62\%$ )	10% ( $\pm 1.62\%$ )
	Surface de l'eau	36 463	90% ( $\pm 2.38\%$ )	10% ( $\pm 2.38\%$ )
	Végétation	103 711	90% ( $\pm 3.47\%$ )	10% ( $\pm 3.47\%$ )
	Bâtiment	25 933	90% ( $\pm 5.53\%$ )	10% ( $\pm 5.53\%$ )
Vert	Surface de l'eau	29 569	90% ( $\pm 3.34\%$ )	10% ( $\pm 3.32\%$ )
	Fond de l'eau	28 787	90% ( $\pm 1.13\%$ )	10% ( $\pm 1.13\%$ )

Table 1: Nombre d'échantillons par classes utilisés pour l'entraînement et la validation. Comme une validation croisée est effectuée, le nombre d'échantillon par entraînement et par test est sensiblement différent.

est de découper aléatoirement les données d'entraînement en un sous-ensemble de  $N$  jeux de données où  $N$  arbres de décision seront calculés. Ces  $N$  arbres pourront s'appuyer sur un nombre réduit de descripteurs afin de s'affranchir de certaines redondances ou biais. Ensuite, chaque point sera classé par chaque arbre et la classe la plus dominante lui sera attribuée. Ainsi, les principaux paramètres du classifieur sont le nombre d'arbres de décision, le nombre de descripteurs utilisés et la profondeur maximum de chaque arbre. Ceux-ci seront déterminés par validation croisée. La contribution de chaque descripteur est ensuite calculée sur la base des erreurs OOB (*Out-Of-Bags*) de chaque arbre.

#### 4.1 Extraction des descripteurs

Nous avons retenu trois familles de descripteurs : ceux s'appuyant sur le voisinage dans un cadre multi-échelle, des descripteurs ponctuels et des descripteurs contextuels.

**Descripteurs multi-échelles.** Comme mentionné précédemment, les descripteurs sont calculés à plusieurs échelles en utilisant les deux canaux disponibles. Trois types de descripteurs ont été retenus dans cet article :

- *Structure 3D.* En s'appuyant sur une analyse en composantes principales, quatre informations pertinentes peuvent être extraites : les trois valeurs propres et l'orientation du nuage de point local, respectivement notés  $\lambda_{1canal}$ ,  $\lambda_{2canal}$  et  $\lambda_{3canal}$  (avec  $\lambda_{1canal} \geq \lambda_{2canal} \geq \lambda_{3canal}$ ) et  $\theta_z$  pour l'orientation du nuage de point. L'indice *canal* indique sur quel canal ces valeurs propres sont calculées. Ainsi,  $\lambda_{1C2}$  indique que cette valeur propre a été calculée sur les points issus du canal PIR (noté  $C2$ ) et  $\lambda_{1C2C3}$  sur les canaux PIR et vert (noté  $C3$ ). Bien que certains auteurs utilisent ces informations pour dériver de nouveaux descripteurs (comme dans [14] où l'omnivariance et la planéarité sont utilisées), nous avons choisi de conserver ces valeurs propres.
- *Structure verticale.* L'altitude est une caractéristique très intéressante pour distinguer des objets dans un environnement naturel. Cependant, la valeur de la coordonnée verticale seule est trop dépendante du type de terrain et de l'acquisition. Ainsi, nous avons préféré

utiliser les écarts-types d'altitude  $\sigma_{zC2}$  et  $\sigma_{zC3}$ , pour les canaux  $C2$  et  $C3$ . La différence des moyennes d'altitude dans le voisinage donné entre le canal vert et PIR est également calculée et notée  $\Delta_z$ . Ainsi, ce descripteur est moins sensible à la nature du terrain et mettra en évidence des structures planes (le sol par exemple) par rapport à des structures plus en hauteur comme des bâtiments ou des arbres. Par ailleurs, la valeur de  $\Delta_z$  permettra de séparer les classes "Sol" et "Surface de l'eau" puisque les propriétés de pénétration dans l'eau ne sont pas les mêmes selon la longueur d'onde utilisée.

- *Intensité.* Le troisième type de descripteur est celui lié à l'intensité *retournée*. L'intensité brute, c'est-à-dire celle mesurée par le capteur, peut être utilisée mais comme nous l'avons déjà mentionné, elle est trop dépendante des conditions d'acquisition (altitude du vol notamment). Il est en revanche possible de calculer une intensité corrigée, mais des paramètres comme l'inclinaison de l'objet scanné doivent être connus [12]. Or, dans notre application, leur accès est difficile, notamment sous la canopée. Ainsi, nous avons choisi de retenir trois descripteurs basés sur l'intensité : les deux écarts-types de l'intensité du canal vert et PIR, notés  $\sigma_{IC2}$  et  $\sigma_{IC3}$ , que l'on suppose indépendants de la hauteur du vol, et le rapport des moyennes d'intensité entre le canal vert et PIR, noté  $r_I$ .

**Descripteurs ponctuels.** Bien que les descripteurs multi-échelles apparaissent plus riches, certaines informations comme la position du point sur le tir, ou encore le ratio de ce dernier sur le nombre de points sur un tir peuvent aider dans la séparation de certaines classes. En effet, les points de sol et surface d'eau étant les derniers points d'un tir, ce ratio peut fournir une information intéressante. Ainsi, on note  $N_r$  le nombre d'échos sur un tir et  $r_p$  le ratio calculé par la position de l'écho sur  $N_r$ .

**Descripteurs contextuels.** Les distances verticales d'un point par rapport au sol et à la surface d'eau les plus proches sont aussi très discriminantes pour certaines classes, comme les bâtiments. Ainsi, nous définissons ces descripteurs contextuels  $d_{ground}^v$  et  $d_{water}^v$ . Ces descripteurs sont calculés par rapport au plus proche voisin, mais ne sont pas dépendants d'une échelle, et sont plus rapides à calculer que les descripteurs liés à une échelle. Afin de pouvoir intégrer ces descripteurs, la classification doit se faire en deux étapes: la première ne garde que le sol et la surface de l'eau, et la deuxième calcule et prend en compte ces descripteurs grâce au résultat de la première étape.

#### 4.2 Approche non-contextuelle

Nous appelons cette approche *non-contextuelle* car les informations liées à la distance au sol ou à la surface de l'eau (descripteurs contextuels  $d_{ground}^v$  et  $d_{water}^v$  vus plus haut) ne sont pas prises en compte, car non accessibles dans un

premier temps. Ainsi, seuls les descripteurs multi-échelles et ponctuels sont utilisés. Une gamme d'échelle, de 0, 25m à 7m, est explorée et la gamme définitive est choisie en fonction des résultats.

Une fois la gamme d'échelle définie, un modèle de forêts aléatoires est appliqué pour la classification du sol, de la végétation, des bâtiments et de la surface de l'eau et la contribution des descripteurs peut être calculée.

### 4.3 Approche contextuelle

Dans cette approche, des descripteurs dits contextuels  $d_{ground}^v$  et  $d_{water}^v$  sont rajoutés. L'approche contextuelle nécessite d'être réalisée en deux fois, car ces descripteurs ne sont pas disponibles dans un premier temps (voir Sec. 4.1). Une pré-classification est donc faite pour extraire le sol et la surface de l'eau du reste. Puis, le calcul des descripteurs contextuels peut être fait en prenant, pour chaque point du nuage d'origine, le plus proche point du nuage pré-classifié. En pratique, pour éviter les problèmes de mauvaises classifications, plusieurs points seront pris en compte et le plus bas sera gardé pour le calcul de la distance.

### 4.4 Classification de la bathymétrie

Afin de classer la bathymétrie (surface de l'eau et fond de l'eau), nous exploitons le canal vert. Étant donné que les morphologies des structures issues des canaux PIR et vert sont très semblables sauf pour la surface de l'eau et le fond de l'eau, la classification du nuage issu de canal vert peut se faire par attribution de la classification du plus proche voisin du canal PIR. Les points qui se seront vu attribuer la classe surface de l'eau sont mis à part, ainsi que les points situés en dessous. Ces points sont des points de bathymétrie et sont séparés en deux classes: la surface de l'eau et le fond de l'eau.

Afin de classer ces points, nous utilisons ici aussi une analyse contextuelle et multi-échelle. La meilleure gamme d'échelle à prendre en compte est obtenue par validation croisée.

Ainsi, deux aspects sont abordés dans cet article. Le premier aspect est de nature topographique, où l'on explore deux approches, l'une non-contextuelle où l'on classe en une seule fois toutes les données, et l'autre contextuelle où une première classification permet de séparer le sol et la surface de l'eau des autres classes afin de calculer des descripteurs contextuels utilisés lors d'une seconde phase de classification de ces données. Le deuxième aspect est de nature bathymétrique. Il intervient après l'aspect topographique où la surface de l'eau est connue, et concerne le nuage issu du canal vert. Dans cet aspect, les données restantes sont à séparer en deux classes: la surface et le fond de l'eau.

## 5 Résultats

Nous avons utilisé la technique de forêts aléatoires construite avec 100 arbres, ayant chacun une profondeur maximale

de 25. Le nombre de descripteurs par arbre est la racine carrée du nombre total de descripteurs (paramètre couramment utilisé). Cette configuration est issue de l'étape de validation croisée.

Nous suivons ici le déroulement vu dans la section 4. Ainsi, l'analyse simple-échelle est d'abord conduite afin de sélectionner la meilleure gamme d'échelle dans le cas mono-spectral. Puis, une comparaison entre le cas mono-spectral et le cas bi-spectral est menée pour pouvoir déterminer les améliorations qu'apporte l'ajout d'un canal, plus particulièrement le canal vert. Ensuite, nous regarderons l'approche contextuelle, permettant de réduire le temps de calcul et idéalement d'améliorer les résultats. Et enfin, la classification de la bathymétrie sera effectuée dans le canal vert par une approche contextuelle pour séparer la surface du fond de l'eau.

### 5.1 Analyse simple-échelle

Comme mentionné dans la section 4.2, une analyse simple-échelle est nécessaire afin de déterminer la meilleure gamme d'échelle à utiliser dans le canal PIR. Nous utilisons les descripteurs multi-échelles  $\lambda_{1C2}$ ,  $\lambda_{2C2}$ ,  $\lambda_{3C2}$ ,  $\theta_z$ ,  $\sigma_{zC2}$  et  $\sigma_{IC2}$  et les descripteurs ponctuels  $N_r$  et  $r_p$ .

La figure 1 montre les résultats, obtenus par validation croisée, avec en abscisse les rayons des différentes échelles utilisées et en ordonnée le coefficient kappa et la précision de chaque classe. La gamme d'échelle de 0, 25m à 3m est donc choisie car le coefficient kappa et la précision de la classe "Végétation" commencent à se détériorer à partir de l'échelle 3m, montrant qu'au-delà de cette échelle, on a plus de confusion dans la séparation des classes.

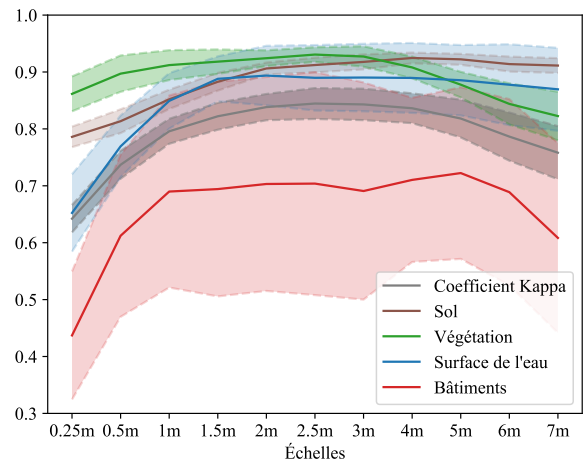


Figure 1: **Classification avec une seule échelle.** Coefficient kappa pour chaque classe en fonction des échelles. Les zones colorées représentent l'écart-type de la validation croisée.

## 5.2 Comparaison entre mono-spectral et bi-spectral dans une approche non-contextuelle

Pour évaluer l'apport de la donnée bi-spectrale dans une approche non-contextuelle, les échelles de 0, 25m, 0, 5m, 1m, 1, 5m, 2m, 2, 5m et 3m sont également choisies afin de pouvoir comparer dans les mêmes conditions les deux expériences.

Ainsi, la figure 2 illustre les différentes performances entre le cas mono-spectral et le cas bi-spectral dans un contexte multi-échelle, que nous comparons également avec celles obtenues pour chacune des classes avec la meilleure échelle. Ces résultats illustrent que les descripteurs multi-échelle améliorent la précision pour toutes les classes, illustrant ainsi le fait que l'information de voisinage est utile à plusieurs niveaux. De plus, l'ajout du canal vert permet également d'améliorer cette précision, notamment pour la surface de l'eau, que ce soit avec le simple-échelle ou le multi-échelle.

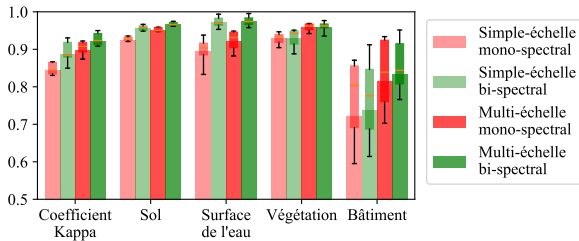


Figure 2: Comparaison de la précision entre le cas mono-spectral et le cas bi-spectral avec une approche simple et multi-échelle. Les boîtes à moustache sont organisées comme suit: l'intérieur des boîtes représentent les résultats entre le premier et troisième quartiles, tandis que les bords des moustaches représentent le premier et neuvième déciles.

Comme mentionné dans la section 4, la classification par forêts aléatoires permet de calculer la contribution de chaque descripteur pour la séparation des classes. Ainsi, la figure 3 montre cette contribution à chaque échelle pour chaque descripteur. Nous pouvons alors voir que le descripteur  $\sigma_{zC2}$  est le plus contribuant, puisque celui-ci peut être attribué à la rugosité dans le cas où le nuage de points local est une surface. En effet, dans ce cas, la rugosité du sol ou de la surface de l'eau ne sera pas très différente, mais sera plus grande dans le cas de la végétation et des bâtiments.

De plus, le descripteur  $\Delta_z$  contribue également de façon significative, puisque celui-ci permet justement de séparer efficacement la surface de l'eau du sol, deux surfaces géométriquement semblables dans le canal PIR mais différentes dans le canal vert. Dans les descripteurs calculés à partir de l'ACP, l'orientation  $\theta_z$  et la valeur propre  $\lambda_{3C2C3}$  sont bien plus contributifs que les deux premières valeurs propres  $\lambda_{1C2C3}$  et  $\lambda_{2C2C3}$ . Les descripteurs liés à l'intensité

sont finalement ceux qui contribuent le moins, les caractères morphologiques étant bien plus importants ici que les valeurs d'intensité rétro-diffusée. Nous analysons à présent les résultats liés à l'approche contextuelle.

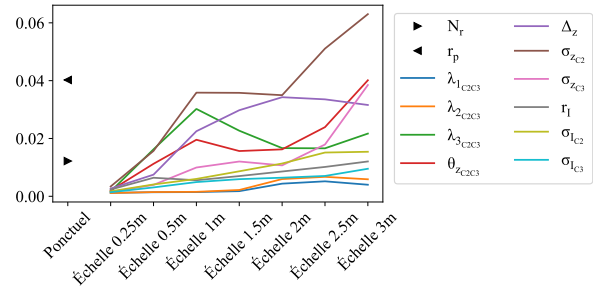


Figure 3: Importance des descripteurs issus de la méthode de forêts aléatoires. Chaque courbe représente l'importance d'un descripteur selon l'échelle. Les descripteurs ponctuels sont représentés à gauche par des points.

## 5.3 Approche contextuelle

Bien que la figure 2 offre de bons résultats ainsi qu'un coefficient kappa élevé avec des données multi-échelles et bi-spectrales (0, 921), cette approche non-contextuelle est également lente car la recherche du voisinage dans une sphère est très coûteuse en temps de calcul. La recherche du ou des plus proches voisins est par contre bien plus rapide à effectuer et les informations liées à la distance verticale du sol ou de la surface de l'eau peuvent être très déterminantes. Nous avons donc exploité cette approche contextuelle après la première phase de classification. Les résultats sont illustrés sur la figure 4 où l'on observe qu'il est possible de réduire la gamme d'échelle de 8 échelles (0, 25m à 3m) à 3 échelles (0, 25m à 1m), ce qui diminue drastiquement l'aspect calculatoire de la méthode. En effet, la recherche dans un voisinage est très gourmande en calcul et est fortement liée à la taille de ce voisinage. Ainsi, en réduisant cette taille, on réduit le temps de calcul.

La figure 5 montre les différences de précision entre des approches non-contextuelle et contextuelle. Elle montre également les précisions selon une approche contextuelle où la pré-classification aurait été parfaite (en exploitant les vraies distances verticales au sol et à la surface de l'eau obtenues par étiquetage manuel) Ainsi, bien que le voisinage soit plus limité, on obtient de meilleures performances grâce à la contribution de ces informations contextuelles. L'apport de ces nouveaux descripteurs est visible sur la figure 6, où l'on peut voir qu'ils ont un rôle dominant, à un niveau équivalent aux descripteurs  $\Delta_z$ ,  $\sigma_{zC2}$ ,  $\theta_z$  et  $\lambda_{3C2C3}$ .

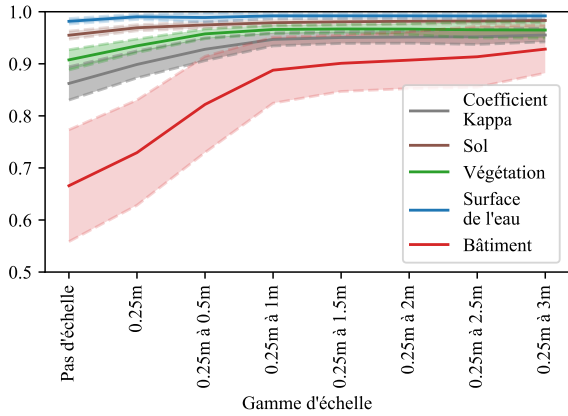


Figure 4: Classification en multi-échelle. Coefficient kappa pour chaque classe en fonction de la gamme d'échelles. Les zones colorées représentent l'écart-type de la validation croisée.

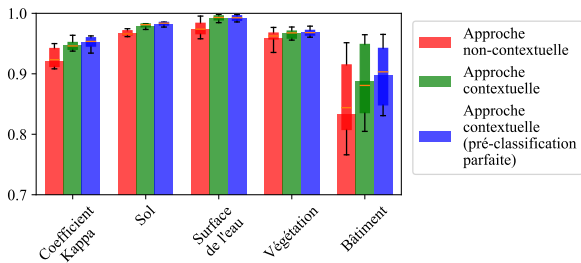


Figure 5: Comparaison entre l'approche non-contextuelle et contextuelle. L'approche contextuelle avec une pré-classification parfaite est également illustrée. Les boîtes à moustache sont organisées de la même manière que dans la figure 2.

#### 5.4 Classification de la bathymétrie à l'aide du canal vert

Comme expliqué dans la section 4.4, tous les points du canal vert sont classés par attribution de la classe du plus proche voisin issu du canal PIR, à l'exception de la surface et du fond de l'eau. Pour ces deux dernières, classées au moyen de la technique présentée en section 4.4, la figure 7 montre les précisions obtenues selon la gamme d'échelle. Ainsi, la gamme d'échelle de 0.25m à 2m suffit pour obtenir un coefficient kappa de 0,98(±0,009) et une précision de 0,992(±0,007) pour la surface de l'eau et 0,99(±0,005) pour le fond de l'eau.

### 6 Conclusion

Dans cet article, nous avons évalué l'impact du LiDAR bi-spectral pour la classification d'objets en milieu fluvial. Pour cela, nous avons défini plusieurs types de descripteurs (ponctuels, voisinage multi-échelle, contextuels) s'appuyant sur le canal proche infrarouge, vert ou sur une

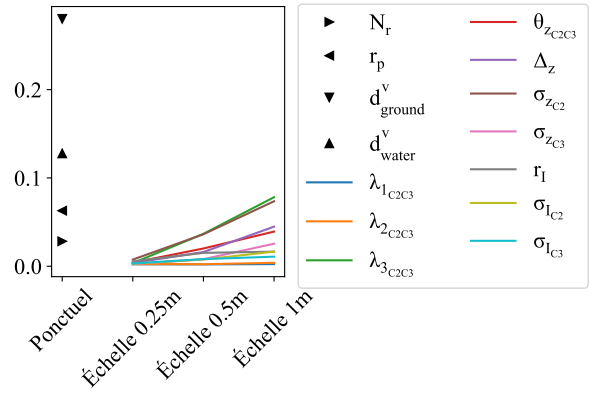


Figure 6: Importance des descripteurs avec l'approche contextuelle. La représentation des données est similaire à la figure 3.

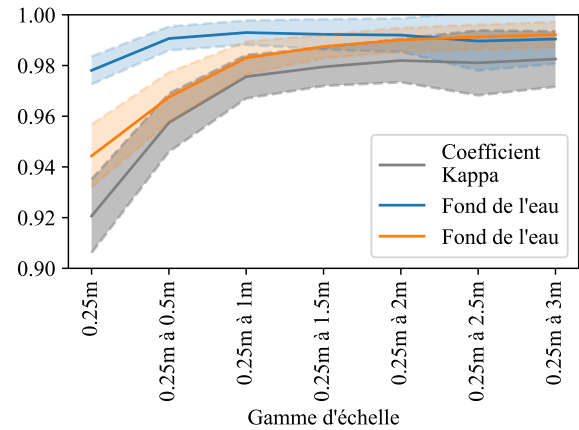


Figure 7: Coefficient kappa et précision pour la surface et le fond de l'eau issus du canal vert.

combinaison des deux.

L'utilisation d'un classifieur de type forêts aléatoires avec ces descripteurs nous a aussi permis de déterminer quels étaient les plus pertinents. Ainsi, l'intensité, bien qu'utilisée dans certaines études, n'a pas montré de réel intérêt dans l'application présentée ici.

L'approche contextuelle a en revanche montré que la détermination des classes dépend fortement de leur distance avec le sol ou la surface de l'eau, ce qui nous semble être une information intéressante pour de telles applications étant donné que les coûts calculatoires sont nettement diminués.

Les descripteurs proposés ouvrent de nombreuses perspectives, et on peut imaginer qu'ils pourraient être utilisés à profit pour la séparation de sous-classes, comme le sol de la route [6], les éléments présents dans l'eau, la végétation aquatique ou encore les rochers, améliorant le suivi environnemental des rivières.

## 7 Remerciements

Nous remercions Électricité de France (EDF) pour l'accès aux données acquises sur l'Ain.

## References

- [1] M. Bartels, H. Wei, and D.C. Mason. DTM generation from lidar data using skewness balancing. In *International Conference on Pattern Recognition (ICPR)*, pages 566–569, 2006.
- [2] R. Blomley, B. Jutzi, and M. Weinmann. 3d semantic labeling of ALS point clouds by exploiting multi-scale, multi-type neighborhoods for feature extraction. In *International Conference on Geographic Object-Based Image Analysis (GEOBIA)*, 2016.
- [3] R. Blomley and M. Weinmann. Using multi-scale features for the 3d semantic labeling of airborne laser scanning data. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2/W4:43–50, 2017.
- [4] L. Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.
- [5] N. Brodu and D. Lague. 3d terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68:121–134, 2012.
- [6] S. Clode, F. Rottensteiner, and P.J. Kootsookos. Improving city model determination by using road detection from lidar data. In *ISPRS Workshop CMRT*, volume 36, pages 159–164, 2005.
- [7] C. Crisci, B. Ghattas, and G. Perera. A review of supervised machine learning algorithms and their applications to ecological data. *Ecological Modelling*, 240:113–122, 2012.
- [8] S. Filin and N. Pfeifer. Neighborhood systems for airborne laser data. *Photogrammetric Engineering & Remote Sensing*, 71(6):743–755, 2005.
- [9] B. Guo, H. Xianfeng, Z. Fan, and S. Gunho. Classification of airborne laser scanning data using JoinBoost. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92:124–136, 2014.
- [10] B. Höfle, M. Vetter, N. Pfeifer, G. Mandlbürger, and J. Stötter. Water surface mapping from airborne laser scanning using signal intensity and elevation data. *Earth Surface Processes and Landforms*, 34(12):1635–1649, 2009.
- [11] B. Ko, H. Kim, and J. Nam. Classification of potential water bodies using landsat 8 OLI and a combination of two boosted random forest classifiers. *Sensors*, 15(6):13763–13777, 2015.
- [12] C. Mallet and F. Bretar. Full-waveform topographic lidar: State-of-the-art. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1):1–16, 2009.
- [13] G. Mandlbürger, M. Pfennigbauer, and N. Pfeifer. Analyzing near water surface penetration in laser bathymetry - a case study at the river Pielach. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-5/W2:175–180, 2013.
- [14] H. Ni, X. Lin, and J. Zhang. Classification of ALS point cloud with improved point cloud segmentation and random forests. *Remote Sensing*, 9(4):288, 2017.
- [15] Z. Pan, C.L. Glennie, J.C. Fernandez-Diaz, C.J. Legleiter, and B. Overstreet. Fusion of lidar orthowaveforms and hyperspectral imagery for shallow river bathymetry and turbidity estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 54(7):4165–4177, 2016.
- [16] C.R. Qi, H. Su, K. Mo, and L. J. Guibas. PointNet: Deep Learning on Point Sets for 3d Classification and Segmentation. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [17] W. Wagner. Radiometric calibration of small-footprint full-waveform airborne laser scanner measurements: Basic physical concepts. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(6):505–513, 2010.
- [18] C.K. Wang and W.D. Philpot. Using airborne bathymetric lidar to detect bottom type variation in shallow waters. *Remote Sensing of Environment*, 106(1):123–135, 2007.
- [19] M. Weinmann, B. Jutzi, S. Hinz, and C. Mallet. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105:286–304, 2015.
- [20] V. Wichmann, M. Bremer, J. Lindenberger, M. Rutzinger, C. Georges, and F. Petrini-Monteferri. Evaluating the potential of multispectral airborne lidar for topographic mapping and land cover classification. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W5:113–119, 2015.
- [21] X.X. Zhu, D. Tuia, L. Mou, G.S. Xia, L. Zhang, F. Xu, and F. Fraundorfer. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4):8–36, 2017.